斜面崩壊の危険度評価におけるニューラルネットワークと最尤法分類の比較

Comparative study on landslide susceptibility mapping between artificial neural network and maximum likelihood method

佐藤 浩^{a)*}・関口辰夫^{a)}・神谷 泉^{a)}・本間信一^{b)}

Hiroshi P. SATO, Tatsuo SEKIGUCHI, Izumi KAMIYA and Shinichi HOMMA

Abstract

Landslide areas were predicted using shift-invariant neural network and maximum likelihood method. To predict the areas, elevation, inclination, and convexity, which are closely related to the landslide, were used as explanatory variables. The predictions were calculated using one variable, two variables, and all three variables. The results were then compared between the two methods. To compare the results, two indices were calculated, one is the landslide correct ratio, which is predicted landslide areas per actual landslide-occurred areas, the other is non-landslide correct ratio, which is predicted non-landslide areas per actual non-landslide areas. If the former ratio is much higher than the latter, it is understood that the result may predict areas of excessive landslide. In this study, it is thought that the higher both ratios are at the same time, the more valid the prediction is.

As a result, both ratios were higher than 70% in some cases using neural network. But no case using maximum likelihood method produced cases where were higher than 70%, and the former ratio (predicted landslide areas) was extremely higher than the latter (non-landslide areas). This result suggests that the neural network method is better than the maximum likelihood method in predicting landslide areas.

Key words : landslide, susceptibility, shift-invariant neural network, maximum likelihood method

和文要旨

シフト不変ニューラルネットワークと最尤法分類を用いて崩壊地点を予測した。崩壊地点を予測するために、説明変数として、斜面崩壊に関わりの深い標高、傾斜、曲率を用いた。1変数のみ、2変数、3変数全てを使った予測を行った。そして、ニューラルネットワークと最尤法分類の予測結果を評価するとともに比較した。結果を比較するために、2つの指標を計算した。1つは、崩壊正解率、すなわち、実際の崩壊地点数のうち崩壊と予測された地点の割合、もう1つは非崩壊正解率、すなわち、実際の非崩壊地点数のうち非崩壊と予測された地点の割合である。もし、崩壊正解率が非崩壊正解率より極端に高いと、その結果は崩壊地点を過剰に予測しているかもしれない。両者の指標が同時に高いほど、結果はより妥当であると考えられる。

本研究の結果、ニューラルネットワークを使ったいくつかの予測の場合では、両者の指標がともに70%を超えることがあったが、最尤法分類ではそのようなことは無く、また、崩壊正解率が非崩壊正解率より極端に高かった。この結果は、崩壊地点の予測には、最尤法分類よりもニューラルネットワークのほうが適切であることを示唆している。

キーワード：斜面崩壊、危険度、シフト不変ニューラルネットワーク、最尤法分類

1. はじめに

わが国は湿潤変動帯に位置し、台風や梅雨時の豪雨によって斜面崩壊が頻発している。また近年の斜面災害の特徴は、高速で長距離を運動する流動性の高い地すべりによるものが注目されるようになってきた(佐々, 2000)。近年、ハザードマップ整備の重要性が指摘されているが、災害研究を行い災害の知見を蓄積しつつある現在、災害に関わる研究者が、災害を確実に予見できるハザードマップ作成のために、どの程度役立つ情報を提供できるか不明である。しかし、ハザードマップの作成を試みることを含めて災害研究を推進することは、国民の生命や財産を守るために重要なことである(藤田ほか, 2001)。

斜面崩壊の研究には、従来の空中写真測量による地形データに加えて、航空レーザ測量による詳細な地形データを利用できるようになった(八木ほか, 2003, Sekiguchi and Sato, 2004)。本研究の目的は、航空レーザ測量で得

られた高精度・高密度の数値標高モデル(Digital Elevation Model; DEM)を使い、ニューラルネットワークと最尤法分類という異なる2つの手法を用いて斜面崩壊の危険度評価を行い、どちらの手法がより妥当な結果を導いているか考察することである。

DEMを用いた斜面崩壊の危険度評価については、これまで多数の研究が行われている。沖村・中川(1988)は六甲山地において崩壊跡地を対象とし、注目地点の傾斜を対数で表示し、その地点より上流の集水面積を対数で表示して、両者に線形の関係を見出した。そして、その回帰直線を判別関数として危険斜面と安全斜面に分類するとともに結果をマッピングした。

説明変数の線形性を前提として目的変数である斜面崩壊を解析する問題点は釜井ほか(2004)によって述べられているが、本研究で適用する2つの異なる手法は、説明変数と目的変数の線形性を前提としていない。つまり、どちらの手法も非線形予測法である。ニューラルネットワークを用いた斜面崩壊の危険度評価については、例えば香月・深和(2002)や釜井ほか(2004)によって行われている。しかし、衛星リモートセンシングデータを使っ

* 連絡著者 / corresponding author

a) 国土地理院地理地殻活動研究センター
Crustal Dynamics Research Center, Geographical Survey Institute
〒305-0811 茨城県つくば市北郷1番
Kitasato-1, Tsukuba, Ibaraki, 305-0811, Japan

b) 国際航業株式会社
Kokusai Kogyo Co., Ltd.

図-1 研究対象地区
Fig. 1 Study area (Hachioji)

た土地被覆分類 (日本リモートセンシング研究会, 2000) によく用いられる最尤法分類を斜面崩壊の危険度評価に適用した例や, ニューラルネットワークと最尤法分類から得られる斜面崩壊の危険度評価の結果を比較して論じた例は, 筆者が知る限りでは無い。

2. 研究対象地区

研究対象地区 (約 1 km^2) は, 八王子市の多摩丘陵の一部である (図-1)。対象地区の北側は多摩川支流の浅川に面する沖積低地 (標高90m), 南側は丘陵地で, 西南西～東北東に延びる標高170～180mの主尾根からなる。主尾根と, 主尾根から北に向かって伸びる支尾根には頂部平坦面と緩い頂部斜面が認められ, 支尾根の間は急傾斜の谷壁斜面と幅の狭い谷底面からなる (田村, 1990)。

対象地区の地質は, 多摩丘陵の基盤である前期更新世の浅海性の礫, 砂, 泥層からなる上総層群が標高166mまでの範囲で東に $1 \sim 5^\circ$ 傾斜して分布し, その上部の標高166m～176mには, 約50万年位前に古相模川によってもたらされた扇状地性堆積物, すなわち, 御殿峠礫層下部の風化礫, 標高176m～182mに御殿峠礫層上部のシルト, 砂, 礫が堆積している。同様に, 御殿峠礫層上部は, 多摩ローム I 層により整合で覆われている (宇野沢・岡, 1972, 岡, 1990)。このように, 対象地区では, 地質の違いが標高の違いに対応している。また, 丹下ほか (1987) は対象地区の東約500mの東京農工大学波丘地試験地において上総層群を2分して, 標高約150mまでの平山砂層, 約150m～166mの砂礫層・礫層・泥岩層からなる連光寺互層を記載しており, 対象地区とはほぼ同様と考えられる。

3. 研究方法

研究対象地区について, 1956年 (昭和31年) から1974年 (昭和49年) までの多時期に撮影された空中写真を判読したところ, 斜面中腹部から発生した多数の表層崩壊

図-2 航空レーザ測量
Fig. 2 Airborne LIDAR survey

の跡地が認められた (Sekiguchi and Sato, 2004)。崩壊跡地の大きさは, 幅10m～25m, 長さ15m～35m (平面距離) と様々であるが, 崩壊跡地の源頭部は, $5 \text{ m} \times 5 \text{ m}$ の広さを単位として十分, 認定が可能だった。そこで, 崩壊跡地の源頭部 (以下, 単に崩壊という) を教師データとし, 2つの異なる手法で崩壊・非崩壊の目的変数を予測した場合, 実際の崩壊の分布と一致するか検証した。説明変数は航空レーザ測量データから得られた標高, 傾斜, 曲率の3変数とした。その理由は, 崩壊が地形と密接に関係していると考えられること, 地形の記載に代表的な変数と考えられること, DEMから広域的に計算できること, そして, 対象範囲のどのグリッドに着目しても他のグリッドと客観的に比較できることによる。

以下, 航空レーザ測量, 教師データと検証データの作成, 航空レーザ測量データから得られる説明変数, そして, 斜面崩壊の危険度評価に用いたニューラルネットワークと最尤法分類の手法について説明する。

3.1 航空レーザ測量

本研究では, 航空レーザ測量データから生成した 5 m グリッドDEMを用いた。航空レーザ測量とは, 航空機から地上に向けてレーザパルスを発射し, 地上で反射されてくるパルスを受光し, その往復時間を計測することにより, 航空機と地上のレーザパルスの反射点との距離を計算して, 地上の三次元座標を正確に計測する手法である。航空機の位置と姿勢 (ω, ϕ, κ) は, 航空機に搭載されたGPS (Global Positioning System) とIMU (Inertial Measurement Unit: 慣性計測装置) によって正確に計測される (図-2)。最終的に, 1パルスごとの地表の反射点の3次元座標の計測が可能となる。本研究では, 対地高度2,500mの航空機から24,000Hzの頻度でレーザパルスを発射することによって, $2.8 \text{ 点}/\text{m}^2$ の密度の反射点データを得た。さらに, 反射点から植生の表面の反射点を除き, 地表面の反射点のみを抽出し, 5 m グリッドDEMをIDW (Inverse Distance Weighted)

図-3 教師エリア (灰) と検証エリア (白) 内の崩壊 (黒) の分布

Fig.3 Source area of landslide (black) in the training (gray) and evaluation (white) data area

法の内挿計算で作成した。その後、トラバース測量による実測検証点の標高を真値として地表面の反射点の標高を検証したところ、平均二乗誤差は0.4m前後であった(佐藤ほか, 2004)。これが、本研究で用いたDEMの計測精度の目安となるが、内挿計算に起因する誤差は考慮していない。

3.2 教師データと検証データの作成

空中写真判読で抽出した崩壊について、DEMと同じ5mグリッドのデータを作成した。判読に用いた空中写真の時期では、対象地区において豪雨以外に著しい崩壊を生じさせるような地震は見当たらない。本研究で予測される崩壊地点とは、いわば、豪雨時の崩壊発生域を想定している。

対象地区では、ほぼ東西方向に支尾根、谷底面が交互に現れ、地層もほぼ水平に堆積していることから、地形・地質が対象地区で均一であると考えた。そこで、図-3に示すように、対象地区のうち航空レーザ測量データの取得範囲を、流域を単位として面積がほぼ同じ2つの部分に分割して、西半分を教師エリア、東半分を検証エリアとした。教師エリアの面積は19.2ha (7,695画素)、検証エリアの面積は19.9ha (7,965画素)である。図-3には、教師エリアと検証エリアのうち、抽出された崩壊を黒色で示した。

教師エリアの崩壊・非崩壊をトレーニングデータとして利用して目的変数をマッピングし、検証エリアの崩壊・非崩壊と比較することによって、2つの異なる手法による崩壊・非崩壊の判断の妥当性を評価した。

3.3 説明変数

3つの説明変数(標高、傾斜、曲率)のうち、標高は、5mグリッドDEMを用いた。崩壊と非崩壊の地形的特徴を踏まえて斜面崩壊の可能性を追求しようとする本研究の目的を考えると、本来であれば崩壊前の地形を再現したDEMを用いるのが妥当である。しかし、崩壊前のDEM

0	1	1	1	0
1	0	0	0	1
1	0	-12	0	1
1	0	0	0	1
0	1	1	1	0

図-4 本研究で用いた曲率の局所オペレータ

Fig.4 Local operator of convexity used in this study

が無いこと、本研究で対象とする表層崩壊は地形を大きく改変するものではないことから、現状のDEMをそのまま採用した。

傾斜は、3画素×3画素(実際の平面で15m×15m、以下、単に3×3)のDEMから計算される平均傾斜を採用した。3×3のDEMを使う理由は、幅5~15m程度の狭い支尾根上の頂部平坦面や支尾根に接する谷壁斜面の傾斜をきめ細かく表現できるためである。

曲率は、5mグリッドDEMに図-4のような5×5の局所オペレータをかけて計算した。これは、-12倍された注目地点の標高から、図-4の12個の1に相当する地点の標高をそれぞれ足し込んでいくことを意味する。もし、平坦地なら注目地点の曲率は0、注目地点が周囲より低いほど曲率はプラスの値が大きく、高いほどマイナスの値が大きい。

通常、画像処理で用いられる局所オペレータのサイズは、3×3である(鳥脇, 1989)。しかし、5mグリッドDEMに対して対象地区の支尾根と谷底面の地形の繰り返しを曲率で表現するとき、3×3のオペレータを用いると、対象地域の曲率のマッピング結果は、ノイズをかけたような画像となり、現地の地形と対応づけることが困難だったこと、5×5のオペレータを用いた曲率のマッピング結果は、現地の遷急線や遷緩線といった地形的特徴をよく捉えた画像であることが判ったからである。

本研究で用いたソフトウェアでは、2つの異なる手法とも、標高、傾斜、曲率の大小を0~255の整数(256階調)にスケールして表現した画像ファイルに変換する必要がある。図-5~図-7に、説明変数として実際に用いた標高、傾斜、曲率の画像ファイルを示す。標高は高いほど白く、傾斜は急なほど白く、曲率は凹であるほど白く表現されている。教師及び検証エリア外は図-5~図-7において、図-3と同様、黒く表示している。

3.4 ニューラルネットワーク

本研究では、ニューラルネットワークの1形態であるシフト不変ニューラルネットワーク(神谷, 2000, 神谷, 2001)を使用した。シフト不変ニューラルネットワーク(以下、単にニューラルネットワークという)は階層型のニューラルネットワークであり、各層にはニューロン(例えば、入力層においては、本研究では各地点が有している3つの説明変数の情報)が3次元的に配置されている(図-8)。このうち、2次元は、対象地域の平面

図-5 標高の画像データ
Fig. 5 Image data of elevation

図-7 曲率の画像データ
Fig. 7 Image data of convexity

図-6 傾斜の画像データ
Fig. 6 Image data of slope

図-8 シフト不変ニューラルネットワーク
Fig. 8 Shift-invariant neural network

的な広がりに対応する (空間軸)。残りの1次元 (z軸方向) は, 入力層においては標高等の入力データの種類, 出力層においては目的変数 (崩壊, 非崩壊) に対応する。z軸方向のニューロンの数を, 入力層について $N_z(1)$, 中間層について $N_z(2)$, 出力層について $N_z(3)$ と表現すると, $N_z(1)=3$ (標高, 傾斜, 曲率の3個を全て用いた場合), 中間層では $N_z(2)$ は任意の数, 出力層では $N_z(3)=2$ (崩壊, 非崩壊の2個) である。本研究では, 特に $N_z(2)=3$ とした。その理由は, 計算量が多いシフト不変ニューラルネットワークを比較的少ない学習回数で安定的に動作させるための条件, すなわち, $N_z(2) \geq N_z(1)$, $N_z(2) \geq N_z(3)$ を共に満たす最小の値だからである。

ニューラルネットワークが最尤法分類と異なる点の1つは, 最尤法分類が注目地点の崩壊, 非崩壊を判断するために注目地点の説明変数の情報しか用いないのに対して, ニューラルネットワークは入力層, 中間層, 出力層の結合の形態 (後述) を変えることによって, 注目地点の近隣の多地点の説明変数の情報を用いることである。

ニューラルネットワークでは, 各地点が, 出力層のニューロンの出力値が最大となる項目 (崩壊か非崩壊か)

に分類される。すなわち, 崩壊ニューロンの出力値が非崩壊ニューロンの出力値より大きい場合, その地点は崩壊と判定される。そして, 適切な分類結果が得られるよう, 説明変数と目的変数の組み合わせを教師として与え, バックプロパゲーション法を用いてニューロン間の結合の重みを予め学習させる。本研究では, 注目地点が教師エリアの崩壊であれば, 崩壊ニューロンの出力値が0.9, 非崩壊ニューロンの出力値が0.1にそれぞれ近くなるように, また, 注目地点が教師エリアの非崩壊であれば, 崩壊ニューロンの出力値が0.1, 非崩壊ニューロンが0.9にそれぞれ近くなるように10,000回, 学習させた。学習の際は, 教師エリアの崩壊の地点と非崩壊の地点について, 「崩壊2乗和」(実際の出力値から目標とする出力値0.9を引いた差の2乗和) と 「非崩壊2乗和」(実際の出力値から目標とする出力値0.1を引いた差の2乗和) を, それぞれ計算した。さらに, これらの2乗和を加えた値 (仮に, E と称する) を計算し, E が最小となるように10,000回学習させた。

また, 学習の振動を抑えるため, 結合の重みの変化項に慣性項 (坂和・田中, 1997) を導入するとともに, 慣性係数 (モーメント係数) $\alpha=0.9$ とした。

図-9 最尤法分類
Fig. 9 Maximum likelihood method

3.5 最尤法分類

最尤法分類は、説明変数のなす多次元空間において、各クラスに属する確率は多次元正規分布にしたがうと仮定したとき、多次元正規分布のパラメータである平均値ベクトルと分散共分散行列は教師の値を用い、注目地点の画素を、(1)式の確率密度 $L_k(X)$ を最大にするクラス k に分類する方法である。

$$L_k(X) = \frac{\exp \left\{ (-1/2)(X - m_k)^T V_k^{-1}(X - m_k) \right\}}{(2\pi)^{n/2} (\det V_k)^{1/2}} \quad \dots\dots(1)$$

ここで、 n 個の説明変数からなるデータにおいて、 $L_k(X)$ は画素データ X におけるクラス k の確率密度、 V_k はクラス k の分散共分散行列、 m_k はクラス k の平均値ベクトル、 $\det V_k$ は V_k の行列式である（日本リモートセンシング研究会, 2000）。

例えば、図-9のように、説明変数として傾斜のみを考えたとき、本研究では教師エリアのデータに基づき崩壊と非崩壊の2つの確率密度関数が得られる。ある注目地点の傾斜が小さかったとき、2つの確率密度関数を参照すると、崩壊よりも非崩壊の確率密度のほうが高い。従って、その地点は非崩壊に分類される。もし、別の注目地点の傾斜が大きかったとき、非崩壊よりも崩壊の確率密度のほうが高ければ、その地点は崩壊に分類される。

4. 結果と考察

4.1 ニューラルネットワークによる評価

(1) 7×7形態の説明変数を用いた場合

広範囲の説明変数の情報が使えるというニューラルネットワークの長所を生かすため、図-10のような、注目地点を中心として7×7の説明変数を用いるような、ニューロンの結合形態（以下、「7×7形態」という）のときの崩壊・非崩壊の分類結果を評価した。図-10では、図の簡単のため、空間軸 x 方向は省略している。

説明変数を1変数だけ用いた場合、2変数用いた場合、3変数すべてを用いた場合について崩壊、非崩壊を評価した。その結果を表-1に示す。検証エリアの7,965画素のうち、実際には「非崩壊」(7,864画素) または「崩

図-10 ニューラルネットワーク (7×7の説明変数を使用) の結合の形態
Fig. 10 Configuration of the neural network (by using 7×7 explanatory variables)

壊」(101画素) であるが、計算の結果、非崩壊であった画素数と崩壊であった画素数をそれぞれ示したものである。また、実際には非崩壊で計算の結果も非崩壊となった画素数の割合を「非崩壊正解率」、実際には「崩壊」であった画素数のうち、計算の結果も崩壊となった画素数の割合を「崩壊正解率」と定義し、非崩壊正解率と崩壊正解率の算術平均を「平均正解率」とした。例えば、表-1の標高1変数を例にとると、非崩壊正解率は、4,093/7,864=0.520、崩壊正解率は、56/101=0.554、平均正解率は (0.520+0.554)/2=0.537である。

ただし、このような評価法だと、過去の崩壊・非崩壊地点の分布のパターンを忠実に再現できないと、崩壊正解率、非崩壊正解率はともに100%とならないことに注意する必要がある。また、それを忠実に再現したとしても、崩壊予測地点を予測する以前に、空中写真を判読して図-3のような過去の崩壊地点をマッピングしておけば足りるので、予測のための計算自体に意味はあまりない。

しかし、斜面崩壊は、空中写真で判読できる程度まで遡れる過去の崩壊地点と同じ地点で生じるとは限らない。また、今後の豪雨に伴う斜面崩壊の発生を待って予測結果を評価することが困難であること、さらに、本研究の目的であるニューラルネットワークと最尤法分類による崩壊・非崩壊の予測の妥当性を調べるには、他に客観的な評価法が見当たらないことから、以上のような正解率で評価を行うこととした。

斜面崩壊の対策のためには、ある程度予測地点を絞り込めるような、より高い崩壊・非崩壊正解率を目指すべきである。本研究では単純に、崩壊・非崩壊正解率が高いほど妥当な結果であると評価する。

表-1において、標高1変数の場合を除き、どの場合の平均正解率も68%以上である。最も平均正解率が高い

表-1 ニューラルネットワーク（7×7の説明変数を用いた場合）による正解率

Table 1 Confusion matrix as a result of neural network (by using 7×7 explanatory variables)

標高			
検証／結果	非崩壊	崩壊	計
非崩壊	4093	3771	7864
崩壊	45	56	101
計	4138	3827	7965

非崩壊正解率 崩壊正解率 平均正解率
0.520 0.554 0.537

傾斜			
検証／結果	非崩壊	崩壊	計
非崩壊	4402	3462	7864
崩壊	12	89	101
計	4414	3551	7965

非崩壊正解率 崩壊正解率 平均正解率
0.560 0.881 0.720

曲率			
検証／結果	非崩壊	崩壊	計
非崩壊	5205	2659	7864
崩壊	29	72	101
計	5234	2731	7965

非崩壊正解率 崩壊正解率 平均正解率
0.662 0.713 0.687

標高と傾斜			
検証／結果	非崩壊	崩壊	計
非崩壊	4148	3716	7864
崩壊	6	95	101
計	4154	3811	7965

非崩壊正解率 崩壊正解率 平均正解率
0.527 0.941 0.734

標高と曲率			
検証／結果	非崩壊	崩壊	計
非崩壊	5229	2635	7864
崩壊	27	74	101
計	5256	2709	7965

非崩壊正解率 崩壊正解率 平均正解率
0.665 0.733 0.699

傾斜と曲率			
検証／結果	非崩壊	崩壊	計
非崩壊	4949	2915	7864
崩壊	12	89	101
計	4961	3004	7965

非崩壊正解率 崩壊正解率 平均正解率
0.629 0.881 0.755

標高と傾斜と曲率			
検証／結果	非崩壊	崩壊	計
非崩壊	5498	2366	7864
崩壊	34	67	101
計	5532	2433	7965

非崩壊正解率 崩壊正解率 平均正解率
0.699 0.663 0.681

図-11 崩壊・非崩壊正解率

Fig. 11 Landslide and non-landslide correct ratios

のは傾斜と曲率 2 変数の場合の 75.5% である。しかし、傾斜と曲率 2 変数の崩壊正解率と非崩壊正解率はそれぞれ 88.1% と 62.9% であり、極端に崩壊正解率が高い結果となっている。崩壊正解率と比較して非崩壊正解率が極めて低いということは、崩壊地点を過剰に見積もっているおそれがある。そこで、表-1 に基づき図-11 のような崩壊・非崩壊正解率をプロットしたグラフを作成した。×印が 7×7 形態の結果を示している。この図と表-1 から判るように、7×7 で両者が 65% 以上あるのは曲率 1 変数、標高と曲率 2 変数、標高と傾斜と曲率 3 変数の 3 つの場合であるが、両者が 70% 以上に達する場合は無い。

(2) 9×9 形態の説明変数を用いた場合

注目地点を中心として 9×9 の説明変数を用いるような、ニューロンの結合形態（図-12、以下、「9×9 形態」という）のときの崩壊・非崩壊の分類結果を評価した。つまり、7×7 形態よりも、より広い範囲の説明変数を使って注目地点の崩壊・非崩壊を予測していることになる。

7×7 形態の場合と同様に、図-11 に●印で崩壊・非崩壊正解率をプロットした。この図を見ると、9×9 形態では、非崩壊正解率は全体として上昇している。また、7×7 形態と比較して、9×9 形態は、非崩壊正解率と崩壊正解率の較差も全体として小さくなっている。表-2 と図-11 において、非崩壊正解率、崩壊正解率ともに 70% を超えているのは 2 つの場合（曲率 1 変数と標高と傾斜と曲率の 3 変数）だった。また、この 2 つの場合は、7×7 形態のときよりも非崩壊正解率、崩壊正解率ともに改善している。標高と傾斜と曲率 3 変数の場合、崩壊正解率は 79.2% であり、曲率 1 変数の 73.3% よりも高い。非崩壊正解率と崩壊正解率の差は、3 変数の場合のほうが曲率 1 変数の場合よりも大きい（8.6% の差）が、非崩壊正解率は、両者ともに変わらない（約 71%）。

そこで、9×9 形態の 7 つの場合を比較すると、標高と傾斜と曲率 3 変数を用いた場合が最も妥当な結果を導いたと考えた。

図-12 ニューラルネットワーク (9×9の説明変数を使用) の結合の形態

Fig. 12 Configuration of the neural network (by using 9×9 explanatory variables)

4.2 最尤法分類による評価

表-3と図-11に、最尤法分類による崩壊・非崩壊正解率を示した。この結果、崩壊正解率は70%を超えているが、非崩壊正解率は、どの変数を用いた場合でも60%を超えることは無かった。また、崩壊正解率と非崩壊正解率の差が著しい(標高1変数の場合を除き、その差は30.7%~44.8%)。

このことから、最尤法分類はニューラルネットワークと比較して、崩壊地点を過剰に見積もっている可能性が高く、本研究で調べた限りにおいては、最尤法分類よりもニューラルネットワークのほうが、崩壊・非崩壊について、より妥当な判断をしていると考えた。その理由として、①特徴空間が異なる(すなわち、最尤法分類は注目地点の特徴のみを考慮しているが、ニューラルネットワークは注目地点のみならず周囲の特徴も考慮している)こと、②最尤法分類は、ニューラルネットワークと異なり特徴空間において崩壊・非崩壊の正規分布を前提としているが、実際、その前提が成り立つ可能性は低いこと、が挙げられる。

4.3 崩壊・非崩壊のマッピング

(1) ニューラルネットワークによる9×9形態3変数の場合

これまでの崩壊・非崩壊正解率の結果と考察を踏まえて、最も妥当な結果を導いたと考えることができる。9×9形態の標高、傾斜、曲率3変数の場合の崩壊・非崩壊の分類結果を示したのが図-13の右側の図である。灰色が予測された崩壊地点で、白色が予測された非崩壊地

表-2 ニューラルネットワーク (9×9の説明変数を用いた場合) による正解率

Table 2 Confusion matrix as a result of neural network (by using 9×9 explanatory variables)

標高			
検証/結果	非崩壊	崩壊	計
非崩壊	4897	2967	7864
崩壊	9	92	101
計	4906	3059	7965

非崩壊正解率 崩壊正解率 平均正解率
0.623 0.911 0.767

傾斜			
検証/結果	非崩壊	崩壊	計
非崩壊	5098	2766	7864
崩壊	29	72	101
計	5127	2838	7965

非崩壊正解率 崩壊正解率 平均正解率
0.648 0.713 0.681

曲率			
検証/結果	非崩壊	崩壊	計
非崩壊	5570	2294	7864
崩壊	27	74	101
計	5597	2368	7965

非崩壊正解率 崩壊正解率 平均正解率
0.708 0.733 0.720

標高と傾斜			
検証/結果	非崩壊	崩壊	計
非崩壊	5197	2667	7864
崩壊	20	81	101
計	5217	2748	7965

非崩壊正解率 崩壊正解率 平均正解率
0.661 0.802 0.731

標高と曲率			
検証/結果	非崩壊	崩壊	計
非崩壊	5363	2501	7864
崩壊	23	78	101
計	5386	2579	7965

非崩壊正解率 崩壊正解率 平均正解率
0.682 0.772 0.727

傾斜と曲率			
検証/結果	非崩壊	崩壊	計
非崩壊	4908	2956	7864
崩壊	9	92	101
計	4917	3048	7965

非崩壊正解率 崩壊正解率 平均正解率
0.624 0.911 0.768

標高と傾斜と曲率			
検証/結果	非崩壊	崩壊	計
非崩壊	5554	2310	7864
崩壊	21	80	101
計	5575	2390	7965

非崩壊正解率 崩壊正解率 平均正解率
0.706 0.792 0.749

表-3 最尤法分類による正解率

Table 3 Confusion matrix as a result of maximum likelihood method

標高

検証/結果	非崩壊	崩壊	計
非崩壊	3795	4069	7864
崩壊	58	43	101
計	3853	4112	7965

非崩壊正解率	崩壊正解率	平均正解率
0.483	0.426	0.454

傾斜

検証/結果	非崩壊	崩壊	計
非崩壊	3921	3943	7864
崩壊	7	94	101
計	3928	4037	7965

非崩壊正解率	崩壊正解率	平均正解率
0.499	0.931	0.715

曲率

検証/結果	非崩壊	崩壊	計
非崩壊	3271	4593	7864
崩壊	25	76	101
計	3296	4669	7965

非崩壊正解率	崩壊正解率	平均正解率
0.416	0.752	0.584

標高と傾斜

検証/結果	非崩壊	崩壊	計
非崩壊	3878	3986	7864
崩壊	6	95	101
計	3884	4081	7965

非崩壊正解率	崩壊正解率	平均正解率
0.493	0.941	0.717

標高と曲率

検証/結果	非崩壊	崩壊	計
非崩壊	3193	4671	7864
崩壊	25	76	101
計	3218	4747	7965

非崩壊正解率	崩壊正解率	平均正解率
0.406	0.752	0.579

傾斜と曲率

検証/結果	非崩壊	崩壊	計
非崩壊	4513	3351	7864
崩壊	12	89	101
計	4525	3440	7965

非崩壊正解率	崩壊正解率	平均正解率
0.574	0.881	0.728

標高と傾斜と曲率

検証/結果	非崩壊	崩壊	計
非崩壊	4444	3420	7864
崩壊	11	90	101
計	4455	3510	7965

非崩壊正解率	崩壊正解率	平均正解率
0.565	0.891	0.728

点である。予測された崩壊地点は、図-3の教師エリアに示した実際の崩壊地点の分布を反映して、概ね、谷頭部や谷壁斜面の、表流水が集まりやすいような凹型斜面で多い。図-13の左側には、対比の便を図るため、図-3に示した検証エリア内の実際の崩壊地点を再掲した。実際の崩壊は以下の3つの標高帯、すなわち標高120m~130m(平山砂層の分布域に相当)、標高150m~160m(連光寺互層の砂礫層の分布域に相当)、標高170m~180m(御殿峠礫層の下部と上部の境界付近に相当)で多発しているようである。

図-13をみると、予測された崩壊地点は、例えばA(120~130mの標高帯に相当)、B(150m~160mの標高帯に相当)のような、主に尾根に接する谷壁斜面(田村,1990)、C(170m~180mの標高帯に相当)のような谷頭部にみられる。

また、Dのような谷底面に近い斜面の曲率が比較的大きいような地点で、実際に崩壊が生じている箇所も崩壊地点と予測されている。

(2) それ以外の場合の代表例

図-13右図との比較のため、図-14に7×7形態(aとb)、9×9形態(c)、最尤法分類(d)による予測結果について、これまで述べた、さまざまな変数の組み合わせのうち代表的なものを示した。灰色が予測された崩壊地点で、白色が予測された非崩壊地点である。使用した説明変数については、図-14のキャプションを参照。

等高線が示す標高と間隔は、図-13と同様であるが、図の見やすさのため、標高値を等高線に付していない。図-13右図と図-14を比較すると、概ね、図-13右図で示した予測された崩壊地点は、図-14にも見られる。しかし、図-13右図において、標高値を「120」と示した場所では崩壊地点が予測されていないのに対し、図-14においてはbを除いて全て、崩壊地点が予測されている。これが図-13右図と図-14の大きな違いである。

図-14aでは、130mの等高線で示される尾根に接した谷壁斜面など、等高線に沿って細い帯状に予測崩壊地点が分布している。

図-14bでは、110mの等高線に沿って、谷壁斜面と谷底面の境界付近や支尾根の部分で、予測崩壊地点が幅広く、帯状に分布している。

図-14cの予測崩壊地点数(表-2より2,368)は、図-14aの予測崩壊地点数(表-1より、2,709)より少ないが、これらの図を見ると分布は似ている。崩壊正解率は両者とも73.3%であるが、非崩壊正解率は、図-14c(70.8%)のほうが図-14a(65.5%)よりも高い。すなわち、図-14aのほうが崩壊地点を過剰に見積もっているようである。

図-14dも、図-14a、図-14cと予測崩壊地点の分布が似ているが、図-14を全体的に見ても、灰色で着色された予測崩壊地点数が明らかに多い。実際、図-14dの予測崩壊地点数は、表-3より3,440個と最も多い。そ

図-13 9×9形態の3変数全てを用いた場合の予測された崩壊・非崩壊地点の分布

Fig. 13 Distribution of predicted failure and non-failure sites (neural network by using 9×9 explanatory variable of elevation, inclination, and convexity)

図-14 予測された崩壊・非崩壊地点の分布

- a: ニューラルネットワーク, 7×7 形態の説明変数が標高・曲率の場合。
- b: ニューラルネットワーク, 7×7 形態の説明変数が標高・傾斜・曲率の場合。
- c: ニューラルネットワーク, 9×9 形態の説明変数が曲率の場合。
- d: 最尤法分類, 説明変数が傾斜・曲率の場合。

Fig. 14 Distribution of predicted failure and non-failure sites

- a: neural network, 7×7 explanatory variable of elevation and convexity
- b: neural network, 7×7 explanatory variable of elevation, inclination, and convexity
- c: neural network, 9×9 explanatory variable of convexity
- d: Maximum likelihood method classification, explanatory variable of inclination and convexity

のため, 非崩壊正解率は57.4%と, 図-14のその他3つの場合と比較しても最も低い。

これらのことから, 過剰な予測崩壊地点の分布が, 非崩壊正解率からだけではなく, 図-14からも読み取れることが判った。ただし, 図-13右図と図-14の予測された崩壊地点の妥当性は, 崩壊・非崩壊正解率に頼らない限り, その分布だけから判断するのは困難である。

5. まとめ

検証エリアにおける崩壊・非崩壊の分布と照らし合せてニューラルネットワークと最尤法分類による崩壊・非崩壊の妥当性を評価したところ, ニューラルネットワークは, 非崩壊正解率と崩壊正解率の差が極端に大きい最尤法分類よりも, 崩壊地点を過剰に予測する可能性は低いことが判った。また, 同じニューラルネットワークでも, 7×7形態よりも9×9形態のほうが, 非崩壊正解率, 崩壊正解率ともに改善する場合が多かった。

また, ニューラルネットワークにおいては, 説明変数の組み合わせに応じて, 崩壊・非崩壊正解率がともに70%を超える場合があることが判った。この結果, ニューラルネットワークが最も妥当な結果を導いたのは, 標高, 傾斜, 曲率3変数を用いた9×9形態の場合(非崩壊正解率70.6%, 崩壊正解率79.2%)であることが示唆された。

今後の展開としては, 他の説明変数を加えて, 崩壊地点の予測をより確からしいものとする工夫が考えられる。説明変数の例としては, 例えば, 5mグリッドDEMを元に流路網を探索して, 地点ごとにそれより上流にある集水面積を集計したデータが挙げられる。本研究の手法を, 標高の違いが必ずしも地質の違いと対応していないような他の地区に適用する場合, 地質の影響をどのように説明変数として扱うかについては, 今後の課題である。

謝 辞

本研究は, 文部科学省科学技術振興調整費「地震豪雨時の高速長距離土砂流動現象の解明」の研究費の一部を用いて行われたものである。

引用文献

- 藤田 崇・横田修一郎・中筋章人 (2001): 斜面ハザードマップの作成とその課題, 応用地質, vol. 41, No. 6, pp. 351-362.
- 釜井俊孝・守隋治雄・笠原亮一・小林慶之 (2004): 地震時における大規模宅地盛土斜面の不安定化予測, 日本地すべり学会誌, vol. 40, No. 5, pp. 389-399.
- 神谷 泉 (2000) シフト不変ニューラルネットワークによる画像の分類. 日本写真測量学会平成12年度秋季学術講演会発表論文集, pp. 311-314.
- 神谷 泉 (2001) シフト不変ニューラルネットワークによる画像の分類(2), 日本写真測量学会平成13年度秋季学術講演会発表論文集, pp. 33-36.
- 香月 智・深和岳人 (2002): ニューラルネットワークを用いた山地流域における斜面崩壊予測に関する研究, 平成14年度砂防学会研究発表会概要集, pp. 122-123.
- 日本リモートセンシング研究会 (2000): 陸域のリモートセンシングによる情報抽出, リモートセンシング通論, pp. 123-224.
- 野上道男 (1998): DEM (数値標高モデル) からDDM (流水線図) を作成するアルゴリズムの改良とC言語プログラム, GIS-理論と応用, Vol. 6, No. 1, pp. 95-102.
- 岡 重文 (1990): 多摩丘陵の地形・地質と土壤・植生, 丘陵地の自然環境-その特性と保全-, 古今書院, pp. 102-108.
- 沖村 孝・中川雅勝 (1988): 数値地形モデルのみによる表層崩壊発生位置予知の一手法, 砂防学会誌(新砂防), Vol. 41, No. 1, pp. 48-56.
- 坂和正敏・田中雅博 (1997): ニューロコンピューティング入門, 森北出版, pp. 27-37.
- 佐々恭二 (2000): 流動性崩壊の発生メカニズム, 流動性崩壊の発生・運動および予測 (日本地すべり学会関西支部シンポジウム), pp. 1-26.
- 佐藤 浩・関口辰夫・織茂 郁・中島 保 (2004): 現地測量の成果を用いた航空レーザー測量DTMの高さ方向の精度検証, 写真とリモートセンシング, Vol. 43, No. 4, pp. 13-21.
- Sekiguchi, T. and Sato, H.P. (2004): Mapping of micro topography using airborne laser scanning, Landslides, Vol. 1, pp. 195-202.
- 田村俊和 (1990): ミクロな自然環境のとらえ方(1) 微地形, 丘陵地の自然環境-その特性と保全-, 古今書院, pp. 47-54.
- 丹下 勲・新藤静夫・野口晴彦 (1987): 第三紀丘陵地(その2), 崩壊の規模, 様式, 発生頻度とそれに関わる山体地下水の動態, 昭和61年度文部省科学研究費自然災害特別研究(1)報告書, pp. 30-41.
- 鳥脇純一郎 (1989): 画像理解のためのデジタル画像処理, 昭晃堂, 181p.
- 宇野沢 昭・岡 重文 (編集) (1972): 1/10,000多摩丘陵北西部関東ローム地質図, 地質調査所.
- 八木浩司・檜垣大助・吉松弘行・相楽 渉・高木洋一 (2003): 空中レーザー高精度地形図地すべり・微地形判読への応用, 地すべり, Vol. 39, No. 4, pp. 35-41.
- (原稿受付2005年4月1日, 原稿受理2005年9月12日)